N°02

RELATÓRIO TÉCNICO

Universidade Federal Rural da Amazônia (UFRA)
Avenida Tancredo Neves, n°2501, Terra Firme, Belém-PA

RELATÓRIO TÉCNICO 02

Universidade Federal Rural da Amazônia
Belém, Pará, 02/06/2020

Aplicação de Redes Neurais Artificiais para Estimativa de Contágio e Óbitos por Covid-19 e Suporte à Tomada de Decisão no Estado do Pará

INTRODUÇÃO

O presente estudo apresenta um modelo de previsão de curto prazo, utilizando a técnica de inteligência computacional conhecida como Redes Neurais Artificiais (RNA), para estimar o número de casos de contágio e de óbitos causados pelo coronavírus SARS-CoV-2 no estado do Pará. O modelo proposto é baseado em dados e toda inferência é feita a partir do conhecimento que se tem a priori. Adicionalmente, este estudo também apresenta a expectativa do dimensionamento dos recursos físicos e humanos em instalações hospitalares. A pesquisa apresenta resultados para todo o estado, bem como microrregiões do Pará, por meio da análise de séries temporais que servem de suporte à tomada de decisão das autoridades públicas.

Uma primeira versão do modelo foi construída para prever o comportamento da epidemia para 30 dias seguintes. O estudo foi publicado em [1]. Posteriormente, com dados mais completos disponibilizados pela SESPA, novos experimentos foram realizados e ajustes aplicados, como a redução do intervalo de previsão para 07 dias. Os resultados destas previsões semanais têm sido apresentados em uma série de Boletins (Boletim Covid-19 Pará), publicados no link: https://proex.ufra.edu.br/boletimcovidufra.

Os dados utilizados neste estudo são públicos, fornecidos pela Secretaria de Estado de Saúde do Pará (http://www.saude.pa.gov.br/coronavirus/), pelo Ministério da Saúde (https://saude.gov.br/) e pelos relatórios da Organização Mundial da Saúde (https://www.who.int/docs/). Foram identificados os padrões comportamentais da sociedade, extraídos para análise os casos ocorridos no estado do Pará e comparados com

os estratos nacionais, continentais e mundiais. Com base neste banco de dados criado, foi usada a série histórica com informações diárias das ocorrências a partir de 18/03/2020, data do primeiro caso de COVID-19 confirmado no Pará.

Uma série temporal é um conjunto sequencial de pontos de dados, medidos ao longo de tempos sucessivos. Na previsão de séries temporais, observações passadas são coletadas e analisadas para desenvolver um modelo que captura o processo de geração de dados subjacentes para a série. Os eventos futuros são então previstos usando o modelo. Esta abordagem é particularmente útil quando não há muito conhecimento sobre o padrão estatístico seguido pelas observações sucessivas ou quando falta um modelo explicativo satisfatório.

As RNAs são capazes fazer aproximação de funções contínuas, podendo ser usadas com sucesso na previsão de séries temporais, tendo a vantagem de aproximar qualquer função não-linear sem nenhuma informação prévia sobre as distribuições estatísticas seguidas pelas observações da série de dados [2-3]. Redes Neurais têm sido usadas para previsões de epidemias e se mostrado superior, em termos de adaptabilidade e resultados, a métodos tradicionais em surtos epidemiológicos emergentes como Ebola, Zika, Síndrome Respiratória no Oriente Médio (MERS), dentre outros [4].

USO DE RNAs EM PREVISÕES EPIDEMIOLÓGICAS

As previsões epidemiológicas podem ser produtos de técnicas estatísticas e algoritmos de aprendizado de máquina com o objetivo de antever surtos de doenças infecciosas. Normalmente, utiliza-se dados demográficos, imunológicos e ou dados geográficos de surtos como dados passados para prever o futuro, momentos de pico e duração de uma epidemia [5]. O processo não precisa entender necessariamente os detalhes da dinâmica da doença, ele visa prever as futuras epidemias usando os métodos mais adequados. A previsão epidêmica é crucial para implementação de medidas eficientes de prevenção e controle de doenças infecciosas [6].

Diferentes tipos de modelos lineares ou não-lineares são usados para prever epidemias [7]. Estes modelos usam séries temporais de dados epidemiológicos para executar previsão de curto ou de longo prazo de uma doença. Metodologias que incorporem a não-linearidade para representar a realidade da dinâmica da doença com alto grau de acerto na previsão são preferidas [8-9].

Diferentes métodos de previsão epidemiológica usam Redes Neurais Artificiais para fazer análise de séries temporais e prever surtos de epidemias [7]. A previsão da prevalência de doenças usando o algoritmo da RNA é uma abordagem amplamente aceita para investigação epidemiológica do tamanho do risco e do surto de doenças [10]. A incidência e prevalência de uma doença pode ser prevista a fim de avaliar o impacto e a exigência de medidas de controle [11]. Um resumo do uso de Redes Neurais Artificiais em previsões epidemiológicas e mostrado na Tabela 1.

A medida da acurácia na previsão de casos epidêmicos ou de mortalidade é importante para se decidir sobre as estratégias de intervenção ou controle. Portanto, compreender as características do modelo ajuda na escolha da melhor abordagem de previsão. Nesta pesquisa, apresentamos o uso de RNAs para problemas de previsão epidemiológica. Uma quantidade considerável estudos já foram realizados em previsão epidemiológica com o uso de RNAs. As RNAs não se limitam à previsão, mas podem realizar também classificação, otimização, estimativa de parâmetros e controle ideal da doença na gestão de epidemias [6].

Tabela 1. Resumo de algumas previsões epidemiológicas usando RNAs. Fonte: [6].

Table 1. Summary of Some Epidemics' Forecasts Using ANNs

Epidemic	Ref.	Network Structure	Input/ Out nodes	Hidden layer/ (nodes) #	Training/ Validation/ Test dataset	Data Normalization	Activation function (hidden/ output)	Training algorithm	Max. Epochs	Performance Measurement
Influenza	4	MLP, RBFN, PNN	26/1	1/ (15,40, 80)	80/10	Binary		BP (Pruning)	600	Mean Error
	10	MLP, FCFF	7/1	1(25)		Linear	Sigmoid	LM	10	MSE, RMSE, MAE, MAPE
HIV/AIDS	33	FF	3/1	4(25, 50 75,100)	26/20	Binary	Tan-sigmoid	BPA	30 000	MAE, R^2
Dengue	34	MLP, FC	12/4	1(3)	50% ratio	Minimax		GA	130	
	35	MLP, FCFF	4(32)/1	1(18-25)	287/72		Cellular automata	GA	30,000	RMSE
Tuberculosis	26	MLP, FC	38	2(50)	150 (50,100)	Binary	Sigmoid	GA		10-fold Cross validation
Malaria	36	GMDH, PNN	4/1	3/ (4-3-2)			Polynomial function	CF		MAPE
	37	MLP, FF FCNN	10-40/1	2(8)			Sigmoid (logistic)	GA	10,000	MAPE
SARS	38	MLP FF FCNN	5/1	1(3)	55(40/15) 41(30/11)	Linear	Sigmoid (logistic) function	BP	1500	SSE
Cholera	39	MLP, FF FCNN	9/1	1/4 (3-19)	80/20%	Linear	Sigmoid/ Linear	LM	20	RMSE
Infectious diarrhoea	40	MLP	5/1	1(3)		Binary	Sigmoid	BP	18000	RMSE
Measles	41	MLP			Jan-Nov 2012/ Dec 2012			BP	2000	
Ebola	42	MLP			Guinea 72 S/Leone 66 Liberia 65		HHT	Grey Model	10,000	MAE
Swine Flu	29	FFNN	10/1	1(14)	80/20%	Binary	Sigmoid	BP		
Cardiovascular disease	43	MLP, FFN	6/1	8-10-12	65/35%		Logistic tanh	BP	3000	R^2, SSE
Dementia	44	MLP PNN	30/1 30/1	4 65	65/25 65/25		Tansig Radial basis function		100	95.9% 97.25%
Typhoid fever	45	RBFNN ERNN BPNN	12/1	2-50/(28)	2005-2009/2010		tanh	RBF BP		MAE, MAPE MSE

BP (back propagation); CF (criterion function); MLP (multi-layer perceptron); FC (fully connected); FF (forward feed); GA (genetic algorithms); GMDH-PNN(group method of data handling-polynomial neural network); LM (Levenberg Marquardt); MAPE (mean absolute percentage error); ME (mean Error); MRE (mean relative error); MSE (mean squared error); PNN (probabilistic neural network); R^2 (coefficient of determination); RBFN (radial basis feed forward network); REP (relative error of prediction); RMSE (root mean squared error); # number.

REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são sistemas de processamento de informações massivamente distribuídos em paralelo, que simulam o funcionamento de neurônios no cérebro humano [12]. O neurônio artificial é a unidade básica de processamento de

informação da RNA. O primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts, em 1943 [13].

Para entender o funcionamento de uma RNA, torna-se importante entender a lógica do funcionamento de um neurônio biológico. O neurônio biológico pode ser dividido em três partes: o corpo celular, os dendritos e o axônio (Figura 1). Os dendritos são ramificações que recebem as informações, na forma de impulsos nervosos, provenientes de outros neurônios e as conduz para o corpo celular. Este processa as informações causando novos impulsos nervosos que são transmitidos através do axônio aos dendritos de outros neurônios. O ponto de contato entre a terminação do axônio de um neurônio e o dendrito de outro é chamado de sinapse. As sinapses são responsáveis pela formação das redes neurais e controlam o fluxo da informação entre os neurônios. Esta transmissão ocorre devido à liberação de moléculas neurotransmissoras que determinam se a sinapse será inibitória ou excitatória [14].

Figura 1. Modelo de um neurônio biológico. Fonte: [15].

As RNAs são alternativas para a regressão e classificação de problemas complexos, por não necessitar de pressuposições sobre as relações entre as variáveis utilizadas no treinamento, ficando a cargo da rede treinada a tarefa de modelar as relações lineares e não-lineares [16][17][18].

As RNAs utilizam a aprendizagem artificial com base no conceito de auto ajuste dos parâmetros de controle interno (pesos). As estruturas matemáticas contidas nos processos

das redes são flexíveis e capazes de identificar relações complexas não-lineares entre conjuntos de dados de entrada e saída [19].

O neurônio artificial em uma arquitetura típica de RNA recebe um conjunto de entradas ou sinais (xm) ponderados por pesos sinápticos (wkm), calcula uma soma ponderada deles (uk) usando a função de soma e então usa alguma função de ativação (φ) para produzir uma saída (yk) conforme a Figura 2 [20][21][22].

Figura 2. Exemplo de um neurônio dentro de uma rede neural artificial MLP (Multilayer Perceptron). Fonte: Adaptado de [20].

Essa sequência pode ser expressa, segundo a Equação 1, em termos matemáticos da seguinte forma [20]:

$$y_k = \varphi\left(\sum_{j=1}^{m} w_{kj} + b_k\right) \quad (1)$$

Em que k e j representam o número do neurônio e da sinapse, respectivamente.

O treinamento de uma RNA inicia pela apresentação dos dados (variáveis de entrada e saída) a uma arquitetura pré-estabelecida ou automatizada por um determinado software. O processo de treinamento inicia com valores aleatórios dos pesos e com base nestes valores a primeira saída é comparada com o respectivo valor real da primeira observação [22]. A diferença entre a saída estimada pela rede e o valor real gera um sinal de erro que calibra o ajuste de pesos iniciando assim um novo ciclo, a fim de aproximar a saída do resultado desejado, ou seja, de minimização do erro [9].

Existem diferentes tipos de RNAs, tais como o Multilayer Perceptron (MLP) [23], sendo que as principais diferenças entre os vários tipos existentes são o arranjo dos neurônios e camadas (arquitetura de rede) e as muitas maneiras de se parametrizar os pesos e funções (treinamento) [14][20]. A rede neural MLP foi projetada para ser aplicada principalmente em fenômenos não-lineares. Uma rede MLP de alimentação adiante (feedforward) consiste em uma camada de entrada, com uma ou mais camadas ocultas (com algum número de neurônios em cada uma), e uma camada de saída [24].

MODELO NEURAL DE PREVISÃO PROPOSTO

Neste estudo, as RNAs treinadas foram do tipo Perceptron de Múltiplas Camadas, conhecidas também como Multilayer Perceptron (MLP), com uma camada oculta. O intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss [24]: $2 \times n0,5 + n2 \leq n1 \leq 2 \times n + 1$; em que n = número de entradas da rede; n1 = quantidade de neurônios na camada oculta; e n2 = quantidade de neurônios na camada de saída. Esse teste no número de neurônios na camada oculta evita o ajuste insuficiente (underfitting) e o ajuste excessivo (overfitting) aos dados [25].

Este trabalho apresenta projeções de curto prazo para óbitos e casos de contágio do estado do Pará e suas microrregiões, além de apresentar projeções de recursos hospitalares. Neste contexto, 4 Redes Neurais foram modeladas (Tabela 2):

Tabela 2. Configurações, Arquitetura e Métricas de treinamento e validação das RNAs

Características das RNAs		RNA 1	RNA 2	RNA 3	RNA 4
Arquitetura		MLP 28-10-2	MLP 130-40-2	MLP 1-6-4	MLP 1-4-10
Treinamento	Correlação	0,99866	0,997247	0,986304644	0,99923
	Erro	0,00002	0,000013	0,00609987	0,00218
Validação	Correlação	0,99702	0,997364	0,984591942	0,99923
	Erro	0,00007	0,000019	0,008327047	0,00218
Algoritmo de Treinamento		BFGS 10000	BFGS 10000	BFGS 440	BFGS 37
Função de Ativação	Camada Oculta	Exponential	Exponential	Logistic	Tanh
	Camada de Saída	Logistic	Identity	Exponential	Exponential

RNA 1	Rede Treinada para o Artigo Científico
RNA 2	Rede Treinada para os Boletins 1 e 2
RNA 3	Rede Treinada para o Boletim 3
RNA 4	Rede Treinada para Dimensionamento de Recursos Hospitalares

Para a RNA 1 - Artigo Científico:

- Variáveis utilizadas para o treinamento e validação da RNA: Estados Brasileiros, Dias Após o Início do Contágio;
- Variáveis dos neurônios da camada de saída: Casos Confirmados e Óbitos Acumulados (Figuras 3 e 4).

Figura 3. Dispersão dos Valores Observados *vs.* Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Casos Confirmados Acumulados (com seleção da MLP 28-10-2)

Figura 4. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Óbitos Acumulados (com seleção da MLP 28-10-2).

Para a RNA 2 - Boletins 1 e 2:

- Variáveis utilizadas para o treinamento e validação da RNA: Municípios do Pará, População e Dias Após o Início do Contágio;
- Variáveis dos neurônios da camada de saída: Casos Confirmados e Óbitos Acumulados (Figuras 5 e 6).

Figura 5. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Casos Confirmados Acumulados (com seleção da MLP 130-40-2).

Figura 6. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Óbitos Acumulados (com seleção da MLP 130-40-2).

Para a RNA 3 - Boletim 3:

- Variáveis utilizadas para o treinamento e validação da RNA: Dias Após o Início do Contágio no Estado do Pará;
- Variáveis dos neurônios da camada de saída: Casos Confirmados e Óbitos Acumulados e diários (Figura 7 a 10).

Figura 7. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Casos Confirmados Acumulados (com seleção da 2.MLP 1-6-4).

Figura 8. Dispersão dos Valores Observados *vs.* Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Óbitos Acumulados (com seleção da 2.MLP 1-6-4).

Figura 9. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Casos Confirmados por dia (com seleção da 2.MLP 1-6-4).

Figura 10. Dispersão dos Valores Observados vs. Preditos das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN para Óbitos por dia (com seleção da 2.MLP 1-6-4).

Para a RNA 4 - Dimensionamento de Recursos Hospitalares:

A Quarta RNA processou o conjunto de observações para inferir, a partir da quantidade diária de óbitos estimadas na etapa anterior; das demandas hospitalares por médico, enfermeiro, fisioterapeutas e técnicos de enfermagem; a partir de dados técnicos da OMS, do Ministério da Saúde, da Associação de Medicina Intensiva Brasileira, do dimensionamento de equipe hospitalar pelos conselhos federais de Medicina, Enfermagem e Fisioterapia, de artigos científicos de Nova York (EUA) e Wuhan (China); considerando a taxa de uso de leitos no pico pandêmico de 2,5 leitos de UTI/10.000 adultos, e a proporção da população por faixa etária do estado do Pará (Figura 11).

Figura 11. Dimensionamento de Leitos de UTI das Cinco Melhores Redes Neurais Retidas na Fase de Processamento SANN (com seleção da 3.MLP 1-4-14).

As funções de ativação testadas foram a exponencial, identidade, logística e tangente hiperbólica. O algoritmo de treinamento utilizado foi o Broyden–Fletcher–Goldfarb–Shanno (BFGS). Os pesos iniciais das RNAs foram gerados aleatoriamente.

A validação das RNAs foi realizada através do particionamento aleatório dos dados em dois conjuntos: conjunto de treinamento (80%) e de validação (20%). Após o treinamento, as cinco melhores redes foram selecionadas com base nas estatísticas de correlação entre os valores observados e preditos – ryŷ (Equação 2), erro médio – Em (Equação 3). Essas redes foram aplicadas nos dados que não foram utilizados no treinamento (conjunto de validação) e avaliadas de acordo com as estatísticas de ryŷ, Em, raiz quadrada do erro quadrático médio - RMSE (Equação 4), erro médio percentual absoluto - MAPE (Equação 5), e gráficos de dispersão dos valores observados vs tendência dos valores preditos em função dos dias.

$$r_{y\hat{y}} = \frac{cov(y,\hat{y})}{\sqrt{s^2(y) \times s^2(\hat{y})}} \quad (2)$$

$$E_m = \frac{1}{2N} \times \sum_{i=1}^{N} (\hat{y}_i - y_i)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N} (\hat{y}_i - y_i)^2}{N}} \quad (4)$$

$$MAPE = \frac{1}{N} \times \sum_{i=1}^{N} |\hat{y}_i - y_i|/y_i \times 100 \quad (5)$$

Em que: s² = variância; cov = covariância; yi = valor observado da i-ésima observação; e ŷi = valor predito da i-ésima observação; N = número total de observações.

Após o cálculo das estatísticas, a análise de sensibilidade foi realizada para identificar a rede com a maior sensibilidade em relação aos dados de entrada, em que quanto maior a sensibilidade, maior será a importância da variável de entrada. Os pesos sinápticos encontram-se em documento anexo a essa Nota.

RESULTADOS

As Redes Neurais Artificiais utilizadas nas previsões de casos confirmados e óbitos para o dia de incidência e acumulados no período, têm seus neurônios artificiais distribuídos nos perceptrons de múltiplas camadas e interligações entre seus pesos sinápticos. A maior validação da acurácia do modelo proposto se mostra quando comparado o conjunto de dados previstos com os dados reais ocorridos, o que reafirma que o modelo neural se comporta bem para modelagem de fenômenos epidemiológicos.

Neste sentido, a Figura 12 apresenta uma satisfatória acurácia entre os resultados reais e preditos com MAPE de 3,73% e RMSE de 9,21, para os dados contidos nos Boletins 1 e 2; e MAPE de 2,29% e RMSE de 501,23, para os dados do Boletim 3.

Figura 13. Previsões de Óbitos para o Estado do Pará.

A partir do dia 20 de maio a SESPA passou a divulgar as informações nos dias em que elas ocorrem, o que permitiu-nos melhorar o processamento de dados e a visualização da existência de diferentes epidemias, de acordo com as diferentes microrregiões e os

municípios, de maneira a evidenciar uma tendência de queda no número de casos diários de infecção e de óbitos nas microrregiões de Belém e Castanhal (Figura 14 e 15). Ainda que uma tendência de redução do número de novos casos seja evidente nessas microrregiões, os dados apontam para uma interiorização da epidemia no estado.

Figura 14. Previsões de Casos Confirmados para as Microrregiões de Belém e Castanhal.

Figura 15. Previsões de Óbitos para as Microrregiões de Belém e Castanhal.

No Boletim COVID-PA número 3, publicado em 28 de maio foi feito o dimensionamento de recursos hospitalares humanos e físicos. Neste diapasão, considerando a atualização da SESPA no portal de informações da COVID-19 no estado do Pará (https://www.covid-19.pa.gov.br/public/dashboard/2e4b12cd-4e12-4aa2-9d7d-1e3cae29a65f#theme=night) em 02 de junho, existem 516 leitos de UTIs e 87.21% estão ocupados, o que corresponde a 450 leitos ocupados, estando assim, 0,44% distante da previsão desse recurso para o período em voga (Tabela 3).

Tabela 3. Dimensionamento de Recursos Hospitalares para o Estado do Pará.

Recurso	27/mai	29/mai	31/mai	02/jun
UTI	529	496	470	448
Leitos Clínicos	1.587	1.489	1.409	1.344
Médico	288	270	256	244
Fisioterapeuta	79	74	70	67
Enfermeiro	317	298	282	269
Técnico de Enfermagem	685	643	608	580

Figura 16. Casos confirmados de COVID-19 por dia em Belém e no Pará.

As curvas por dia de ocorrência de óbitos e casos confirmados no estado do Pará (Figura 16) mostram uma tendência de queda, todavia, é possível notar uma diferença de observações entre as datas do dia 01 de junho e 26 de maio (início da divulgação dos casos diários pela SESPA), essa diferença refere-se a evolução da contaminação para o interior do Estado, visto que, para o dia 01 de junho, a curva para a cidade de Belém, de casos confirmados e óbitos (Figura 17), está menos expressiva quando comparada com a curva maior do estado do Pará. Ademais, ainda é possível perceber que o comportamento de

queda é o mesmo entre as duas observações temporais do Estado, alterando a magnitude da doença no período em que ela ocorre.

Figura 17. Casos por COVID-19 por dia em Belém e no Pará.

CONSIDERAÇÕES FINAIS

O presente estudo apresenta um modelo de previsão baseado em aprendizado de máquina, através da técnica de Redes Neurais Artificiais, com o objetivo de produzir projeções de curto prazo, trazendo a vantagem para os formuladores de política públicas aplicarem melhor os recursos ou planejar intervenções mais ágeis no período de pandemia no estado do Pará.

Este estudo não pretende realizar uma previsão de dados que não são notificados, devido a falta de documentação completa e a tempo destes casos. Isso representa uma característica epidemiológica crítica na modulação da possível propagação de um vírus respiratório emergente como o SARS-CoV-2. Essas infecções passam despercebidas e,

dependendo de sua capacidade de transmissibilidade e de contágio, podem expor uma parcela muito maior da população ao vírus do que normalmente ocorreria.

Também não se pretende apresentar aspectos referentes a outras variáveis como o isolamento social e densidade demográfica. Isso poderia acarretar na exigência de maior custo computacional aumentando o tempo de execução. A proposta destes boletins é gerar informes semanais e por essa característica é importante ter projeções viáveis e satisfatórias de serem publicadas a tempo hábil.

As informações apresentadas a cada atualização nos boletins semanais retroalimentam e melhoraram a acurácia do próprio modelo de previsões, o que nos permite ter uma visualização mais ampla do fenômeno na observação do dia em que de fato é registrado o óbito e atestado o caso. Dessa maneira, as conexões sinápticas entre os neurônios artificiais da rede buscam modelar o fenômeno para o dia de ocorrência e não apenas aos valores acumulados. Neste contexto, para a região metropolitana de Belém, o modelo de Redes Neurais Artificias usado reforça a tendência de queda de casos confirmados de pessoas sintomáticas que buscaram o sistema de saúde por evolução do quadro clínico, bem como aos casos de óbitos.

Logo, os dados gerados e apresentados são informes que podem ajudar na tomada de decisão, mas sem pretensão de ser o único olhar sobre a pandemia no estado. Destaca-se que o poder público pode fazer uso dos dados gerados com a devida parcimônia, levando em consideração os objetivos expostos que indicam uma análise de curto prazo. Assim sendo, outras pesquisas e fontes de análises podem estar presentes em tomadas de decisões mais bruscas como a continuidade ou o fim do isolamento social, já que estas necessitam de outras apreciações

#fique em casa

EQUIPE DE TRABALHO

A equipe que desenvolve esta pesquisa é multidisciplinar e conta com profissionais das áreas da Saúde, Virologia, Engenharia, Biologia Computacional, Modelagem Matemática e Inteligência Computacional.

Prof. Marcel Botelho
Doutor em Educação e Desenvolvimento Local
UFRA – Reitor

Prof. Jonas Castro
Doutorando em Ciências Florestais
UFRA – Pró-Reitor Adjunto de Extensão

Profa. Silvana Rossy
Doutora em Engenharia Elétrica
UFRA – Pró-Reitora de Planejamento e Des. Instituc.

Prof. Marcus Braga
Doutor em Genética e Biologia Molecular
Bioinformática
UFRA - Núcleo de Pesquisas em Computação Aplicada

Prof. Gilberto Nerino
Doutor em Engenharia Elétrica
(Computação Aplicada)
UFRA – Campus Paragominas

Prof. Rafael Fernandes
Doutor em Engenharia de Produção
UFRA – Campus Parauapebas

Profa. Adriana Folador
Doutora em Genética e Biologia Molecular
Bioinformática
UFPA – Instituto de Ciências Biológicas

Prof. Rommel Ramos
Doutor em Genética e Biologia Molecular
Bioinformática
UFPA – Instituto de Ciências Biológicas

Prof. Carlos Maneschy
Doutor em Engenharia Mecânica
Secretário de Estado da SECTET
Presidente da FAPESPA

Prof. Antonio Vallinoto
Doutor em Ciências Biológicas (Virologia)
UFPA – Instituto de Ciências Biológicas

Andrea de Souza
Fisioterapeuta
Especialista em Terapia Intensiva

Cristina Kameyama
Fisioterapeuta
Concrem Wood

Felipe Jatene
Médico
Estado de São Paulo

Helloyza Pompeu
Residente em Enfermagem
UEPA

Ivaldo Tavares
Doutorando em Ciências Florestais
UFV

Raphael Pinheiro
Graduando em Engenharia Florestal
UFRA – PROEX

REFERÊNCIAS

[1] JONAS ELIAS CASTRO DA ROCHA, GILBERTO NERINO DE SOUZA JÚNIOR, SILVANA ROSSY DE BRITO, ADRIANA RIBEIRO CARNEIRO FOLADOR et al. **Redes neurais artificiais na previsão de contágio e óbitos por covid-19: um estudo no estado do Pará, Brasil**. International Journal of Development Research, 10, (04), 35416-35421.<https://www.journalijdr.com/redes-neurais-artificiais-na-previs%C3%A3o-de-cont%C3%A1gio-e-%C3%B3bitos-por-covid-19-um-estudo-noestado-do-par%C3%A1>

[2] OANCEA, B., & CRISTIAN CIUCU, Ş. **Time Series Forecasting Using Neural Networks. Challenges of the Knowledge Society**. IT in Social Sciences, 1402–1408, 2013.

[3] G. ZHANG, B.E. PATUWO, M.Y. Hu. **Forecasting with artificial neural networks: The state of the art**. International Journal of Forecasting 14, pages: 35-62, 1998.

[4] WU JT, COWLING BJ. Real-time forecasting of infectious disease epidemics. Hong Kong Med J. 24 Suppl 6(5):26-9.[4] Breu F, Guggenbichler S, Wollmann J. **Utilization of Neural Network for Disease Forecasting**. Vasa [Internet]. Available from: http://medcontent.metapress.com/index/ A65RM03P4874243N.pdf. , 2018.

[5] PINTER, GERGO AND FELDE, IMRE AND MOSAVI, AMIR AND GHAMISI, PEDRAM AND GLOAGUEN, RICHARD. **COVID-19 Pandemic Prediction for Hungary; A Hybrid Machine Learning Approach, 2020**. Available at SSRN: https://ssrn.com/abstract=3590821 or http://dx.doi.org/10.2139/ssrn.3590821

[6] DATILO et al. **A Review of Epidemic Forecasting Using Artificial Neural Networks**. Int J Epidemiol Res, Volume 6, Issue 3, 2019.

[7] BHARAMBE AA, KALBANDE DR. **Techniques and approaches for disease outbreak prediction: A survey**. Proceedings of the ACM Symposium on Women in Research 2016. Indore, India: ACM. p. 100-2, 2016.

[8] TABATABA FS, CHAKRABORTY P, RAMAKRISHNAN N, VENKATRAMANAN S, CHEN J, LEWIS B, et al. **A framework for evaluating epidemic forecasts**. BMC Infect Dis.;17(1):345. doi: 10.1186/ s12879-017-2365-1, 2017.

[9] SATISH S, SMITHA GR. **Epidemic Disease Detection and Forecasting: A Survey**. International Journal of Advance Research, Ideas and Innovations in Technology. 3(2):384-6, 2017.

[10] BREU F, GUGGENBICHLER S, WOLLMANN J. **Utilization of Neural Network for Disease Forecasting**. Vasa [Internet]. Available from: http://medcontent.metapress.com/index/ A65RM03P4874243N.pdf. , 2008.

[11] BARIDAM B, IROZURU C. **The Prediction of Prevalence and Spread of HIV/AIDS Using Artificial Neural Network–the Case of Rivers State in the Niger Delta, Nigeria**. Int J Comput. Appl.44(2):42-5, 2012

[12] HAYKIN, S. **Neural networks and learning machines**. New Jersey: Prentice Hall, 2009.

[13] McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

[14] BRAGA, A. P.; FERREIRA, A. C. P. L.; LUDEMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. LTC Editora, 2000.

[15] CERRI, R. **Redes neurais e algoritmos genéticos para problemas de classificação homogênea multirrótulo**. 175 p. Tese (Doutorado) - Universidade de São Paulo - São Carlos, 2014.

[16] DIAMANTOPOULOU, M. J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v. 105, n. 3, p. 306–315, 2010.

[17] ÖZÇELIK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT, H. V. **Estimating tree bole volume using artificial neural network models for four species in Turkey.** Journal of Environmental Management, v. 91, n. 3, p. 742–753, 2010.

[18] NUNES, M. H.; GÖRGENS, E. B. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in Brazil. **PLoS ONE**, v. 11, n. 5, p. 1–16, 2016.

[19] MELESSE, A. M.; HANLEY, R. S. Artificial neural network application for multi-ecosystem carbon flux simulation. **Ecological Modelling**, v. 189, n. 3–4, p. 305–314, 2005.

[20] HAYKIN, S. **Redes neurais**: Princípios e prática. 2. ed. Porto Alegre: Bookman, 900p, 2001.

[21] LIU, R.; YANG, B.; ZIO, E.; CHEN, X. Artificial intelligence for fault diagnosis of rotating machinery: A review. **Mechanical Systems and Signal Processing**, v. 108, p. 33–47, 2018.

[22] RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: A modern approach**. 3. ed. New Jersey: Prentice Hall, 2010.

[23] SOARES, P. L. B.; SILVA, J. P. da. Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada**, v. 3, n. 2, p. 58-72, set., 2011.

[24] SILVA, I. N.; SPATTI, D. H.; FLAUZIN, R. A. **Redes neurais artificiais**: para engenharia e ciências aplicadas. São Paulo: Artliber. 396 p. , 2010.

[25] REIS, L. P.; DE SOUZA, A. L.; MAZZEI, L.; DOS REIS, P. C. M.; LEITE, H. G.; SOARES, C. P. B.; TORRES, C. M. M. E.; DA SILVA, L. F.; RUSCHEL, A. R. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **Forest Ecology and Management**, v. 382, p. 161–167, 2016.